Escola de Verão: Corpora, ...

J.João Dias de Almeida

11 de Setembro de 2006

Estratégia prevista

1. Criação de corpus de domínio específico
   - BootCat e NetBootCat
2. Criação de corpora: corpora paralelos
   - Philip Resnick – Mining the web for bitexts
   - Estratégia parguess

Outline

Corpus de domínio específico

(BootCat e NetBootCat: Baroni, et al)

- dado uma lista **boa** de 20 termos técnicos semente,
- gerar aleatoriamente 100 subconjuntos de 4 termos
- pesquisar o Google e obter 3 URL para cada subconjunto
- ir buscar cada um desse 300 ficheiros
- limpá-los e juntá-los
- processá-los
- –> corpus temático

Outline

Criação de corpora paralelos

(= Criação de memórias de tradução)

1. Encontrar *Bitexto**
2. Alinhar à frase
3. Exportar em formatos públicos (Ex TMX, TEI)

- ... Philip Resnick
- ... Parguess
- Alinhamento de textos paralelos

Philip Resnick – Mining the web for bitexts

1. Algumas páginas bilingues...

2. Expressão de pesquisa tipo

```
     (anchor:"portuguese" OR anchor:"portugues")
AND (anchor:"english"    OR anchor:"ingles")
AND NOT "dictionary"
```

3. produz uma base de dados de candidatos a Bitextos
4. quem quiser usa-a
5. faz a validação
6. problemas: qualidade muito variável

Estratégia parguess

1. Parte de uma lista de URLs ou de ficheiros **name.paths**:
   - Partindo de uma lista of URLs:
     - robot específico
     - contribuição de (....)
   - Partindo de um (ou mais) sites (qualidade mais controlada):
     1. ... eventualmente usar expressões de pesquisa para detectar bisites
     2. wget do site
     3. lista = lista dos ficheiros (`find`)

```
http://www.ex.pt/ingles/index.html
http://www.ex.pt/portugues/index.html

http://www.ex.pt/index_pt.html
http://www.ex.pt/index_en.html
```

2. Analisando Cria uma lista de blocos candidatos **name.blocks**

Processamento

1. Procura candidatos a bitextos **name._pairs**:
   $web \vee directory \rightarrow Bitexto*$
2. Validação **name.pairs**:
   $Bitexto* \rightarrow Bitexto*$
3. Segmentação à frase:
   $Bitexto* \rightarrow (F^* \times F^*)^*$
4. Alinhamento à frase:
   $(F^* \times F^*)^* \rightarrow ((F \times F)^* \times id^2)^*$
5. seguidamente:
   1. ... cria TMX (em corpus.pt.fr.**name.pt.fr.tmxdir/name.pt.fr.tmx**)
   2. ... alinha à palavra
   3. ... extrai exemplos

Validação de bitextos

- language identification / checking
- file type validation
- file size comparison
- filename similarity checking
- non-text contents comparison

Man `mkterminum`

```
NAME
      mkterminum - makes text alignment, build TMX paralell corpora

SYNOPSIS
       mkterminum [-id=name] [-l1=pt] [-l2=fr] dir [output]
       mkterminum [-l1=pt] [-l2=fr] f.paths [output]
       mkterminum [-l1=pt] [-l2=fr] f.blocks [output]
       mkterminum f.en.pt._pairs [output]

DESCRIPTION
      Depending on the arguments (input / output) some of the fol
      lowing steps are done

 0      dir                          directory
 1   dir    -> paths         .paths   list of files
 2          -> blocks        .blocks  list of blocks
 3          -> _pairs        ._pairs  list of bitext candidate pairs
 4          -> pairs         .pairs   list of bitext
 5          -> tmx           .tmxdir  directory with the TMXs

      If we want just to calculate the tmx for a set of bitexts, we cr
```

Demonstração

- analisa site http://www.panda.com
- extrai, traduz para P, alinha,
- cria várias tmx
- `tmx2tmx -cat *.tmx`
- cria um página de perquisa HTML
- cria uma dicionário probabilístico de tradução (Natools)
- cria um stardict

Demonstração

1. descarregar

```
wget http://www.panda.com  (demorou horas)
```

2. Tratar dos zips

```
for a *.zip; do jjzip $a ; done
```

3. mkterminum -skipch -patt4pdf -max10

```
./es_des_hl_titanium2005.chm
./es_des_hl_invent.zip.dir/pinv3_sp.cnt
./es_des_hl_invent.zip.dir/pinv3_sp.hlp
./de_des_gu_enterprisecure.zip
./es_des_gu_webadmin.zip
./fr_des_hl_platinumis.zip
./en_des_ft_platinum7.zip
./es_des_gr_businessecure.zip
./es_des_hl_trupreventcorp.chm
./fr_des_hl_titanium2005.zip
./es_des_gu_titanium.zip
./en_des_gr_adminsecure.zip
./de_des_gr_trupreventcorp.pdf
```

Demonst...

```
portuguese => ./pt_des_gr_businessecure.pdf
french => ./fr_des_gr_businessecure.pdf
%
portuguese => ./pt_des_gu_titanium.pdf
french => ./fr_des_gu_titanium.pdf
%
portuguese => ./pt_des_gr_titanium2005.zip
french => ./fr_des_gr_titanium2005.zip
%
portuguese => ./pt_des_hl_titanium.zip.dir/IHFAQS.GIF
french => ./fr_des_hl_titanium.zip.dir/IHFAQS.GIF
%
portuguese => ./pt_des_hl_titanium.zip.dir/IcoOso3.gif
french => ./fr_des_hl_titanium.zip.dir/IcoOso3.gif
%
french => ./fr_des_gr_businessecure.zip
portuguese => ./pt_des_gr_businessecure.zip
%
portuguese => ./pt_des_hl_titanium.zip.dir/IArchivo.GIF
french => ./fr_des_hl_titanium.zip.dir/IArchivo.GIF
```

Demo...

```
./pt_des_gr_businessecure.pdf    ./fr_des_gr_businessecure.pdf
./pt_des_gu_titanium.pdf         ./fr_des_gu_titanium.pdf
./pt_des_gr_titanium2005.zip     ./fr_des_gr_titanium2005.zip
./pt_des_hl_titanium.zip.dir/IcoOso3.gif
./fr_des_hl_titanium.zip.dir/IcoOso3.gif
./pt_des_gr_businessecure.zip    ./fr_des_gr_businessecure.zip
./pt_des_hl_titanium.zip.dir/IArchivo.GIF
./fr_des_hl_titanium.zip.dir/IArchivo.GIF
./pt_des_hl_titanium.zip.dir/IOtrosp.GIF
./fr_des_hl_titanium.zip.dir/IOtrosp.GIF
./_.pt.fr.tmxdir/_.pt.fr.tmx-pt ./_.pt.fr.tmxdir/_.pt.fr.tmx-fr
./_.pt.fr.tmxdir/_.pt.fr.tmx-fr ./_.pt.fr.tmxdir/_.pt.fr.tmx-pt
./pt_des_hl_platinum7.zip        ./fr_des_hl_platinum7.zip
./pt_des_hl_titanium2004.chm     ./fr_des_hl_titanium2004.chm
./pt_des_gr_platinum7.zip        ./fr_des_gr_platinum7.zip
./pt_des_gr_sendmailsecure.pdf   ./fr_des_gr_sendmailsecure.pdf
./pt_des_gr_exchangesecure.zip   ./fr_des_gr_exchangesecure.zip
./pt_des_hl_trupreventcorp.chm   ./fr_des_hl_trupreventcorp.chm
```

Dem...

```
./pt_des_gr_businessecure.pdf    ./fr_des_gr_businessecure.pdf
./pt_des_gu_titanium.pdf         ./fr_des_gu_titanium.pdf
./pt_des_gr_sendmailsecure.pdf   ./fr_des_gr_sendmailsecure.pdf
./pt_des_gr_dominosecure.pdf     ./fr_des_gr_dominosecure.pdf
./pt_des_gr_businessecureex.pdf  ./fr_des_gr_businessecureex.pdf
./pt_des_gr_platinumis.pdf       ./fr_des_gr_platinumis.pdf
./pt_des_gr_qmailsecure.pdf      ./fr_des_gr_qmailsecure.pdf
./pt_des_gu_titanium2005.pdf     ./fr_des_gu_titanium2005.pdf
./pt_des_gr_titanium2005.pdf     ./fr_des_gr_titanium2005.pdf
./pt_des_gr_pavclsecure.pdf      ./fr_des_gr_pavclsecure.pdf
./pt_des_gu_platinum7.pdf        ./fr_des_gu_platinum7.pdf
./pt_des_gr_adminsecure.pdf      ./fr_des_gr_adminsecure.pdf
./pt_des_gr_platinumis2005.pdf   ./fr_des_gr_platinumis2005.pdf
./pt_des_gu_enterprisecure.pdf   ./fr_des_gu_enterprisecure.pdf
./pt_des_gr_isasecure.pdf        ./fr_des_gr_isasecure.pdf
./pt_des_gr_mimesecure.pdf       ./fr_des_gr_mimesecure.pdf
./pt_des_gu_titanium2004.pdf     ./fr_des_gu_titanium2004.pdf
./pt_des_gr_exchangesecure.pdf   ./fr_des_gr_exchangesecure.pdf
./pt_des_gr_proxysecure.pdf      ./fr_des_gr_proxysecure.pdf
./pt_des_gr_cvpsecure.pdf        ./fr_des_gr_cvpsecure.pdf
./pt_des_gr1_gdef.pdf    ./fr_des_gr1_gdef.pdf
```

De...

```
****** alinhamento... _+(pt fr)
...

-rw-rw-r--   1 jj jj  37199 Jul 12 09:46 _.1.pt.fr.tmx
-rw-rw-r--   1 jj jj 130012 Jul 12 09:46 _.2.pt.fr.tmx
-rw-rw-r--   1 jj jj  49519 Jul 12 09:46 _.3.pt.fr.tmx
-rw-rw-r--   1 jj jj  10653 Jul 12 09:46 _.4.pt.fr.tmx
-rw-rw-r--   1 jj jj  34449 Jul 12 09:46 _.5.pt.fr.tmx
-rw-rw-r--   1 jj jj 260554 Jul 12 09:47 _.pt.fr.tmx
  5439  31763 260554 _.pt.fr.tmx
```

D...

```
<tu><!--1:1-->
  <tuv lang='pt'><seg>INSTALAR O PANDA BUSINESSECURE REQUISITOS MÍNIMO
  INSTALAÇÃO Requisitos mínimos para instalar o Panda ClientShield Pro
  :</seg></tuv>
   <tuv lang='fr'><seg>INSTALLATION DE PANDA BUSINESSECURE CONDITIONS
 D'INSTALLATION Conditions minimum pour installer Panda ClientShield P
  :</seg></tuv>
</tu>

<tu><!--1:1-->
  <tuv lang='pt'><seg>Disco rígido :</seg></tuv>
  <tuv lang='fr'><seg>Disque dur :</seg></tuv>
</tu>

<tu><!--1:1-->
  <tuv lang='pt'><seg>Sistema operativo :</seg></tuv>
  <tuv lang='fr'><seg>Système d'exploitation :</seg></tuv>
```

Outline

Dicionários Probabilísticos de Tradução

```
coruja =>                  enorme =>
   count => 36,               count => 45,
   trans =>                   trans =>
       owl      => 97 %           large      => 42 %
       vacuum   =>  2 %           huge       => 23 %
       forward  =>  1 %           enormous   => 13 %
                                  (none)     => 11 %
                                  deep       =>  4 %
                                  ...
```

Formalmente

$$word_{\mathcal{L}_\alpha} \mapsto (occurrences \times word_{\mathcal{L}_\beta} \mapsto \mathcal{P}(\mathcal{T}(word_{\mathcal{L}_\alpha}) = word_{\mathcal{L}_\beta}))$$

Extracção de Exemplos

	não	i no	podemos	tolerar	que	la	comisión	continúe	jugando	al	gato	y	al	ratón	!
não	0.4	83.2	0.0	0.0	0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
podemos	0.0	0.0	73.8	1.8	0.4	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
tolerar	0.0	0.0	0.0	72.9	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
por	0.0	0.0	0.0	0.0	1.5	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
mais	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
tempo	0.0	0.0	0.0	0.0	0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
que	0.0	0.1	0.0	0.0	74.7	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0
a	0.3	0.3	0.0	0.0	2.0	52.9	0.0	0.0	0.0	1.7	0.0	0.4	1.3	0.0	0.0
comissão	0.0	0.0	0.0	0.0	0.0	0.0	92.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
continue	0.0	0.0	0.0	0.0	0.0	0.0	0.0	33.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0
este	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
jogo	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
do	0.0	0.0	0.0	1.0	0.5	0.8	0.0	0.0	0.0	1.5	0.0	0.0	1.4	0.0	0.0
gato	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	75.6	0.0	0.0	1.0	0.0
e	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	83.2	0.0	0.0	0.0
do	0.0	0.0	0.0	0.7	0.3	0.6	0.0	0.0	0.0	1.2	0.0	0.0	1.5	0.0	0.0
rato	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	39.1	0.0
!	1.4	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	79.1

não	i no
podemos	podemos
tolerar por mais tempo que	tolerar que
a	la
comissão	comisión
continue este jogo do gato	continúe jugando al gato
e do rato	y al ratón
!	!

D 2: dicionários probabilísticos + exemplos -> Stardict

Demonstração criar um dicionário stardict com base em dicionários probabilísticos + exemplo

```
#!/usr/bin/perl
use NAT::Client;

my $dir = shift;
my $dic = do "dir/target-source.dmp";

my $corpus = NAT::Client -> new ( local => $dir );

PARA CADA PALAVRA $w do dic {
   next unless relevante($w);
   PARA CADA TRADUÇÃO $t COM PROB. > 0.2 {
      # pesquisa coocorrências  $w $t no servidor
            $concs = $corpus->conc({direction=>'<->'},  $t, $w);
      # guarda o primeiro exemplo
            $dic->{$w}{sample}{$t} = $concs->[0];

print Dumper($dic);

sub relevante {...  }
```

Stardict

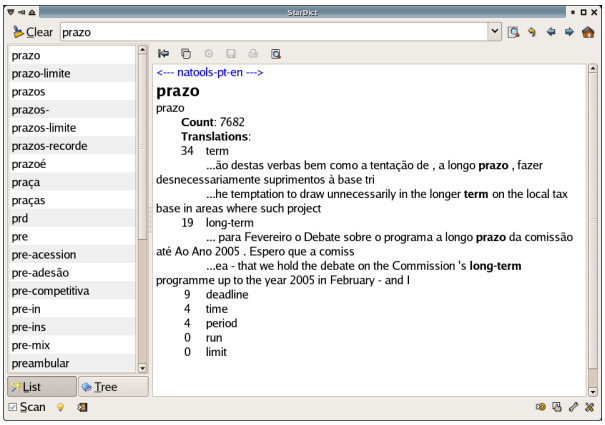

Outline

Exemplo

CP2-3 Mas como, se muitas não dispõem, nos seus quadros, dos técnicos necessários?

Lingua::Treebank::SimTreeML

```
<extract>
  <source>CP2-232 ... de idade...  </source>
  ...
  <tree cat='pp' fun='N<'>
    <t cat='prp' lema='de' fun='H'>de</t>
    <t cat='n' lema='idade'... fun='P<'>idade</t>
  </tree>
  ...
<extract>
```

Exemplo de SimTreeML

```
<extract>
 <source>CP2-3 Mas como, se muitas não dispõem, .....dos técnicos
     necessários?  </source>
 <tree cat="fcl" fun="QUE">
   <t cat="conj-c" lemma="mas" fun="CO">Mas</t>
   <t cat="adv" lemma="como" fun="ADVL">como</t>
   <punct ort=","/>
   <tree cat="fcl" fun="ADVL">
     <t cat="conj-s" lemma="se" fun="SUB">se</t>
     <t cat="pron-det" lemma="muito" fun="SUBJ">muitas</t>
     <t cat="adv" lemma="não" fun="ADVL">não</t>
     <t cat="v-fin" lemma="dispor" args="PR 3P" fun="P">dispõem</t>
     <punct ort=","/>
     <tree cat="pp" fun="ADVL">
       <t cat="prp" lemma="em" fun="H">em</t>
       <t cat="adj" lemma="necessário" args="M P">necessários</t>
     </tree>
   </tree>
   <punct ort="?"/>
 </tree>
</extract>
```

Padrão de processamento

```
func downTr(p:DisTab): ANY
 r = <>
 ParaTodos ( {tree in treebank : filter(tree)} )
    let ( f   = p["-end"] or id )
          res = f( proc(tree ,p ) )
    in  push(r, res)

 return r
}

func proc(TXT(pc), p:DisTab) = pc

func proc(XML(ele,att,sons), p:DisTab) =
 let( f = p[e] or p["-default"] or toxml,
      v = att
      c = strcat(<proc(son,p) | son in sons >)
 in f(c,v)
}
```

Compilar a gramática

```
use Lingua::Treebank::SimTreeML
    dir=> "/opt/treebanks", id => "tb1";

compileTB("/share/tb1.xml")
```

Get the metadata

```
use Lingua::Treebank::SimTreeML
   dir=> "/opt/treebanks", id => "tb1";

print Dumper(getmeta())
```

Resultado:

```
{
 trees => 5216
 nt    => { np     => 26197,
            pp     => 20170,
            fcl    =>  9301,
            icl    =>  2147,
            vp     =>  2001, ...  },

 t     => { n      => 24254,
            prp    => 20636,
            art    => 18569,
            conj-c =>  3401 ...} }
```

Extracção de dicionários simples

```
use Lingua::Treebank::SimTreeML
   dir=> "/opt/treebanks", id => "tb1";

downTr({
   t => sub{ $dic->{$c}{"$v{cat}, $v{lemma}"}++ }
});

print Dumper $dic;
```

produzindo:

```
{a          => { 'art, o'             => 5748,
                 'prp, a'             => 2502, },
 desaparece => { 'v-fin, desaparecer' => 1 },
 reformas   => { 'n, reforma'         => 9 },
 dotar      => { 'v-inf, dotar'       => 3
 ...
},
```

Extrair uma gramática probabilística a partir dum treebank

```
downTr({tree => sub{ $c = norm($c);
                     $prod{"$v{cat} --> $c"}++;
                     return $v{cat} },
           t => sub{ return "[$v{cat}]" },
       punct => sub{ return "'$v{ort}'" } });

for(sort {$prod{$b} <=> $prod{$a}} keys %prod)
   { print "$_ $prod{$_}\n";}

sub norm{ ...}
```

...obtendo-se:

```
pp       --> [prp] np              13639
np       --> [art] [n]              4248
np       --> [art] [n] pp           3527
np       --> [art] [prop]           2331
pp       --> [prp] [n]              1790
np       --> [n] pp                 1214
pp       --> [prp] icl              1128
pp       --> [prp] [prop]           1060
np       --> [art] [n] [adj]         964
np       --> [pron-det] [n]          872
icl(pcp) --> [v-pcp] pp              679
vp       --> [v-fin] [v-pcp]         575
icl      --> [v-inf] np              561
np       --> [n] [adj]               541
np       --> [art] [pron-det] [n]    469
...  e muitas mais produções...
```

Alterar a floresta sintática!

```
<t cat="v-fin" lemma="estar" args="..." fun="P">estava</t>
```

...toda de modo a criar novas categorias **ser-v...** para as formas do verbo **ser, estas e ter**

```
%toBeChanged=(ser => 1, ter => 1, estar => 1);

downTr({
 -end => sub { print $c },
  t   => sub{ if ($toBeChanged{$v{lemma}}){
                    $v{cat}= "$v{lemma}-$v{cat}" };
              return toxml} });
```

Obtendo-se...

```
<t cat="estar-v-fin" lemma="estar" args="..." fun="P">estava</t>
```

Outline

Outline

Conclusões

1. importância de composicionalidade
2. importância de dispor de corpora localmente!
3. programas podem ser pequenos!
4. programar pode ajudar a fazer estragos...
5. efeito multiplicativo